

## 加速度データ自動セグメンテーションに基づく 行動認識手法の性能評価

大村 廉<sup>†1</sup> 橋田 尚幸<sup>†2</sup> 今井 倫太<sup>†3</sup>

本稿では、加速度データと半教師付き学習を用いた行動認識手法において、加速度データに対して自動セグメンテーション手法を利用して再学習のためのデータを取得する手法を提案する。一般に半教師付き学習では確信度や複数の識別器の合意により再学習に使用されるデータの採否が決定されたが、このことは再学習時の学習効率の低下や精度向上の頭打ちの一因となっていた。本稿で提案する手法では、識別器の出力には非依存な自動セグメンテーション結果によって対象となるデータ範囲を決定し、この範囲の識別結果が一定の割合以上で同一の識別結果を得た場合にはこの行動範囲のデータ全てを再学習用のデータとすることでこの問題を解決する。6つの加速度センサを利用して7種類の日常行動について取得した実験データに対して提案手法を適用して評価を行った。この結果、提案手法では、15分程度の再学習データを用いることで、教師付き学習と同程度の識別精度を達成することができ、提案手法が効果的に作用することを確かめた。

### Evaluation of Activity Recognition with Auto-segmentation of Accelerometer Data

REN OHMURA,<sup>†1</sup> NAOYUKI HASHIDA<sup>†2</sup> and MICHITA IMAI<sup>†3</sup>

This paper proposes a method that efficiently collects reinforcing data by adopting automatic segmentation technique to accelerometer data. Semi-supervised learning methods choose, in general, reinforcing data based on confidence values of a classifier or agreement among classifiers. However, this can cause inefficient reinforcement and/or limitation of accuracy improvement. The method we propose in this paper split data into segments where each activity continues by an auto-segmentation technique, and whole data in a segment is exploited for reinforcement after obtaining same classification results over certain ratio in the segment. Some experiments were conducted using six accelerometers with seven target daily activities. The results showed that proposed method obtained the same accuracy as supervised learning with fifteen minutes reinforcement learning and support the advantage of the method.

### 1. はじめに

コンテキスト・ウェアサービスの実現を目的として、ユーザの行動を自動的に認識する手法の研究が多くなされている。中でも、加速度センサをユーザの手や足に装着して体の各部位の動きを取得し、パターン認識の手法を用いて行動識別を行う手法は、精度の高さや小型・軽量で比較的容易に装着できること、また、環境への非依存性などから、多くの研究がなされている<sup>2),5),7)</sup>。

しかし、教師付き学習に基づくパターン認識による手法では、事前に取得した加速度データに行動ラベルを付与してシステムの学習データとする必要があり、特に高精度の識別を達成するためには大量の学習データを取得する必要がある。さらに、より高精度の識別を行うためには、不特定多数のユーザから得られた学習データよりも、識別対象となるユーザから得た学習データを用いる必要があることが指摘されている<sup>2)</sup>。このことは、実際に行動認識を用いたアプリケーションに対して、ユーザに事前のデータ取得を強要することとなり、また、学習データとするためのラベル付け作業は大変な手間であることから、その実現のための大きな障害となる。

この問題に対応する手法の一つとして、半教師付き学習 (Semi-supervised Learning) による手法が検討されている<sup>4),8)</sup>。半教師付き学習では、初めに少量の学習データを用意し、このデータを用いて初期の識別器を学習しておく。その後、未知のデータに対してこの識別器を用いて識別結果を出力し、その出力結果を基に識別器を再学習する。このようにすることで、学習データの用意を少量にとどめ、未知データの識別とともに大量の学習データを得て、最終的に大量の学習データを対象ユーザから大量に集めて時と同様の結果を得ようとするアプローチである。

しかし、半教師付き学習では、人手によるラベル付けのような正確さが期待できない。仮に間違ったデータを採用して再学習した場合、その後の再学習では将棋倒し的に間違ったラベル付けがなされ、大幅な学習の質の低下を招く可能性がある。このため、半教師付き学習

†1 豊橋技術科学大学  
Toyohashi University of Technology

†2 大日本印刷株式会社  
DaiNippon Printing CO.,Ltd.

†3 慶應義塾大学  
Keio University

では確信度や複数識別器による出力結果の合意など、識別結果の確度を基に再学習用のデータとして取捨選択を行う。

一方で、このような確度の高いデータは、ほとんどの場合現在までに学習したデータに類似したデータとなる。このため、モデルの識別精度改善に対する寄与は制限され、再学習における識別精度改善の効率低下や識別精度向上に対する頭打ちの原因となってしまう。

そこで本稿では、行動の自動セグメンテーションに基づく半教師付き学習による行動認識手法を提案する。提案手法では、波形の自動セグメンテーション手法を用いて、加速度データから同一の行動が連続する範囲を特定する。この範囲のデータ全体に対する識別結果を基に、範囲内のデータに対する再学習への採用 / 非採用を決定することで、個々の識別では確度が低いデータをも再学習に取り込めるようにし、上記の問題を解決する。以下、次章にて、既存手法における問題点について説明する。次に、3章および4章で提案手法と、提案手法で用いる波形データの自動セグメンテーション手法について述べる。そして、5章にて提案手法の有効性を示すための実験とその結果について述べる。

## 2. 半教師付き学習とその問題点

Stikic らは、半教師付き学習の有効性を検証するため、家庭環境内における9種類の行動の認識について、Self-Training による手法と Co-Training による手法の評価を行っている<sup>8)</sup>。Self-Training 手法では、少量のラベル付きデータを用いて初期識別器の学習を行い、その後、この識別器を用いてラベル無しデータのラベル付けを行い、確信度の高いラベル付けがなされたデータを用いて識別器の再学習を行っている。また、Co-Training 手法では1つのイベントから得られる加速度データおよび赤外線センサーのデータについて、それぞれ独立に識別器を学習させ、初期のラベル付きデータ以降は各々の識別器の出力結果とその確信度を共有して再学習データへの採否を決定してデータの採用の機会を増やしている。しかし、識別率はいずれの場合においても同量のデータを教師付き学習によって学習に使用した場合より大きく下回っており、再学習による精度改善効率に対して改善の余地があることを示している。

6) では、この問題について指摘がなされており、新規学習データの採用戦略として「確信度による選別」を行うことで、既得のクラス間での分離平面からより離れたデータを再学習に利用することができる一方で、そうして選別されたデータがモデルの再学習において、新たな情報を提供しにくいといった問題点を指摘している。すなわち、図1に示すように、確信度が高いラベル付けがなされたデータ(図中A)は、既得の識別モデルにとって

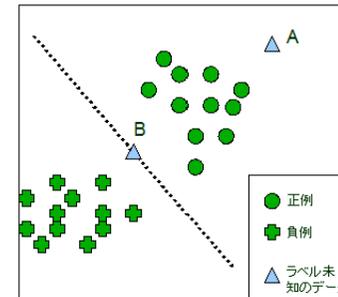


図1 2クラス間の分離境界と再学習用のデータ点  
Fig. 1 Classification Boundary and Resampled Data in Two Classes

「典型的なデータ」であるため、そのラベル推定の信憑性が高いとしても、再学習に用いられた際に識別モデルのパラメータの大きな更新には至らない。一方で、不明瞭な(確信度の低い)データ(図中B)を採用することができれば、大きく分離境界を更新し、識別精度の大幅な改善に貢献する可能性が高い。

Guan らの研究では、複数の識別器を用いて結果を出力し、その結果の多数決によって再学習データへの採否を決定する手法を提案している<sup>4)</sup>。しかし、この手法では複数の識別器の出力が一致する必要があり、確信度といった明示的な値ではないものの、「どのような識別器を用いても同じ出力が得られる」というような、やはり「典型的なデータ」ばかりが新規教師データとして採用されてしまう可能性が高い。

このような問題を解決するため、識別器の「確信度」や「多数決」を直接用いることなく再学習に採用するデータを決定する必要がある。より具体的には、識別器による出力には非依存となる指標を考慮して再学習への採否を決定することで、識別器に対しては「不明瞭」なデータを採用する可能性を高め、再学習による識別精度の大幅な改善を促すことができると考えられる。

## 3. 提案手法

本研究では、前章での述べた半教師付き学習における識別精度改善効率の問題を解消するため、加速度データに対する自動セグメンテーションを用いた手法を提案する。具体的には、加速度データに対する自動セグメンテーション手法によって行動の移り変わりを検出し、一定の行動がとられた区間について、再学習のデータとしての採否を決定するようにする。

加速度データを用いた行動識別において、取得される加速度データは以下のような特徴を持っている。

- 同種の日常行動はある程度連続して発生する  
「歩いている」「走っている」等の単位で日常行動を識別することを想定した場合、それらの行動が数秒の間に次々と遷移することはあまりない。通常ならば、人間が何らかの意図をもって行動を起こすとき、それらの行動は少なくとも数秒から数十秒は継続すると考えられる。
- ほぼ絶え間なくデータを獲得することができる  
例えば音声認識における音声データはユーザが発話している間しか取得できないのに対し、多くの場合、行動識別のための加速度データはセンサが稼働している限り定期的には得られる。低消費電力化のための駆動制御を考慮しなければ、被験者が身動きを取らない場面においても加速度データを取得し、その時点での姿勢を識別対象とする場合が多い。

このような加速度データの特徴から、本研究では連続する同種の行動の検出に着目した。尚、従来研究の半教師付き学習手法では、こうした行動データの連続性が考慮されることはなかった。

まず、時系列の波形データに対する自動セグメンテーション手法を用いて加速度データの変化点を検出し、セグメントに分割する。この変化点を行動の移り変わりの時点と考え、一つのセグメントの間は同一の行動が続けられているとみなす。そして、対象となるセグメントについて、現在の識別器を用いて識別を行い、セグメント内のデータへの推定ラベルが一定以上の割合で同種のものである場合に、そのセグメント内のデータをすべて教師データとして採用する。

この手法により、推定されたラベルの信憑性を維持しつつ識別器の出力に依存しないデータの採用を促すことができ、既得のモデルの更新に大きく貢献するデータが再学習に利用されやすくなると考えられる。

#### 4. 自動セグメンテーション方法

前述のように、行動の遷移を検出するため、本研究では音声認識における音素セグメンテーションの基本的な手法として知られる、スペクトル遷移度のピーク検出による音素のセグメンテーション手法<sup>3),10)</sup>を用いる。スペクトル遷移度 (Spectral Transition Measure) $G(t)$  は以下の式により定義される。

$$G(t) = \left( \sum_{i=1}^p a_i^2 \right) / p \quad (1)$$

$$a_i(t) = \frac{\sum_{n=-M}^M C_i(t+n)n}{\sum_{n=-M}^M n^2} \quad (2)$$

ここで、 $C_i(n)$  は時刻  $n$  (  $n$  番目のウィンドウ ) における  $p$  次元の周波数領域での特徴量の  $i$  次係数であり<sup>3)</sup>、 $C_i$  ではメルケプストラム係数が用いられている。 $M$  は対象となるウィンドウの前後のウィンドウ数を表す。すなわち、上記の式は、対象ウィンドウ前後の周波数領域での特徴量の変化率を算出し、その 2 乗平均をスペクトル遷移の尺度とみなすことに相当する<sup>3)</sup>。ここでは、このスペクトル遷移度のピークを検出して、自動的な音素セグメンテーションが行われている。

本研究では、スペクトル遷移度を加速度センサのデータに適用するにあたり、その特徴量としてケプストラム係数を用いる。そして、スペクトル遷移度  $G(t)$  を計算し、そのピークを行動の遷移点としてとらえ、加速度データのセグメンテーションを行う。

#### 5. 実験

本研究では、以下の手順で提案手法の有効性を確認する。

- 実験 1 自動セグメンテーション手法による行動の分割の検証  
まず、提案手法で前提とする自動セグメンテーション手法が適切に行動の遷移点を検出できているかどうかの確認を行う。
- 実験 2 提案手法による行動しい別精度改善の評価  
次に、提案手法および従来手法における識別精度改善の比較を行う。  
以下、まず実験に用いた機材やデータ収集条件などの実験環境について述べ、次に使用した特徴量及び識別アルゴリズムなどの識別方法について述べる。そして、上記の実験の内容の詳細と、その結果について述べる。

##### 5.1 実験環境

加速度センサはワイヤレステクノロジー社の小型無線加速度センサ WAA-001<sup>1)</sup> を使用した。被験者には加速度センサを両上腕、両大腿、両足首の計 6カ所に装着してもらった。

また、被験者には「歩いている」「走っている」「立っている」「座っている」「階段を上っている」「階段を下りている」「コンピュータ作業」の計 7種類の行動を行ってもらった。この時、単に行動名を依頼するのみであり、各行動の詳細な動きについては、実験者側からは

何も指示は行わなかった。

## 5.2 特徴量と識別アルゴリズム

各加速度センサはそれぞれ 50Hz で記録し、窓幅 5.12 秒、ずらし幅 2.56 秒 (50%) の矩形窓を用いて部分系列に分割した。部分系列の各軸からそれぞれ平均、標準偏差、エネルギーを求めて特徴量とした。

また、識別アルゴリズムについては先行研究である 8) に倣い、Joint Boosting<sup>9)</sup> を用いた。Joint Boosting は多クラス間の識別に対応したブースティング手法である。入力ベクトルデータを  $v$  とすると、クラス  $c$  についてのモデル  $H(v, c)$  は多数 ( $M$  個) の弱識別器  $h_m(v, c)$  のスコアの合計により出力が決定される。

$$H(v, c) = \sum_{m=1}^M h_m(v, c) \quad (3)$$

$$h_m(v, c) = \begin{cases} a\delta(v^f > \theta) + b\delta(v^f \leq \theta) & (c \in S(n)) \\ k_c & (c \notin S(n)) \end{cases} \quad (4)$$

すなわち、ベクトル中のある属性値が閾値を超えるか否かにより  $a, b$  いずれかのスコアを返すという単純な弱識別器の合計でその出力が決定する。Joint Boosting ではこの弱識別器をクラス集合のサブセット  $S(n)$  間で共有し、サブセット  $S(n)$  に含まれないクラスに関しては定数  $k_c$  を返す。データが入力されると、クラス毎に  $H(v, c)$  が計算され、その中で最大の値に該当するクラスに分類される。

また、従来手法と比較のため、従来手法における確信度による再学習用データの採用基準は以下の通りである。

(1)  $H(v, c)$  が単一のクラス  $c$  についてのみ正値をとるデータ  $v$  を審査対象とする ( $H(v, c)$  の値がクラス間で僅差となる場合、 $v$  に対してラベル付けされる  $c' = \arg \max_c H(v, c)$  が不確かなものとなるため)

(2) (1) を満たす  $v$  について、確信度  $conf$  を

$$conf = H(v, c') - \sum_{c \neq c'} H(v, c) \quad (5)$$

とみなす

(3) 各ラベル毎に上位の  $conf$  値をとるデータ  $v$  を採用する。

## 5.3 実験 1:自動セグメンテーション手法による行動の分割

まず、4 章で述べた、自動セグメンテーションにより、行動の移り変わりを適切に検出できるかどうかを確認を行った。実験において右手首の加速度センサから取得した加速度データを基に算出したスペクトル遷移度 ( $G(t)$ ) と、正解ラベルとして記録したその時のハンドアノテーションの内容の例を図 2 に示す。

尚、スペクトル遷移度の算出にあたり、各パラメータは以下のように設定した。

- 注目前後フレーム数  $M = 30$
- 注目するケプストラム係数の次数  $p = 10$

すなわち、今回はスペクトル遷移度を算出するにあたり、対象フレーム前後約 1 分間に注目したケプストラム係数の変化率を利用している。

図 2 から、ハンドアノテーションによる行動の界線とスペクトルピークが概ね合致していることが見て取れる。特に「走っている」や「歩いている」の行動開始点・終了点では、非常に正確に境界線とスペクトルピークが重なっており、適切にその遷移が取得出来ていることがわかる。これらの 2 つの行動については、行動が続いている途中のスペクトル遷移度の値が非常に低い。これは、「走っている」や「歩いている」のような周期的な運動について、ケプストラム係数の値が安定しやすいためスペクトル遷移度が低くなり、さらに行動の遷移時にはケプストラム係数の値の変化が際立つためにピークが現れやすいのだと考えられる。

対して、「立っている」「座っている」「コンピュータ作業」の様な動きの少ない行動については、実際には行動が遷移していないにも拘らず、スペクトル遷移度の小規模のピークが現れている。これらの行動では運動に規則性がないため、低次ケプストラム係数の値が安定し難く、スペクトル遷移度の値に反映されてしまった結果だと考えられる。例えば「立っている」や「座っている」といった動作のデータの取得中では、被験者がリラックスしている場合、姿勢を崩す動作が不定期に発生する。このような瞬間によって、加速度センサからスペクトル遷移度のピークが現れ、行動遷移点の誤検出に繋がってしまっているものと考えられる。

ただし、期待されないスペクトル遷移度のピークが得られてしまった場合でも、本来の連続する同種行動のセグメントを細分化するに過ぎない。このため、次の識別器による識別結果において、その前後のセグメントは同一の行動として認識され再学習用のデータに採用されることになる。むしろ、本来であれば行動の遷移が存在する点を検出できない場合の方が大きな問題となる可能性がある。本来連続していない点を連続していると誤認識することで、異なったラベルの学習が進んでしまう可能性がある。その点で、誤検出によって

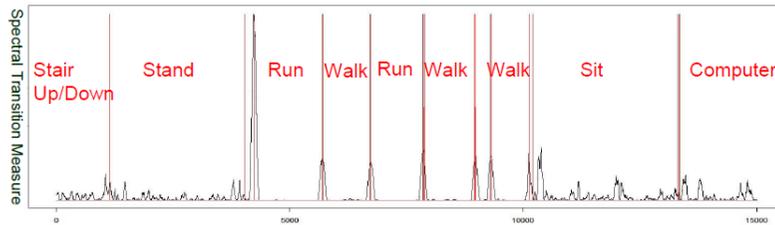


図 2 自動セグメンテーション手法による行動遷移の抽出例  
Fig. 2 Example of Activity Transition Detection by Auto-Segmentation

表 1 提案手法によって採用された新規学習データの量  
Table 1 Amount of Resampled Training Data by Proposed Method

	ラベル無データ量	新規教師データ量
コンピュータ作業	33.5 分	19.1 分
走っている	31.0 分	30.1 分
座っている	33.2 分	15.7 分
階段を下りている	27.0 分	3.6 分
階段を上っている	28.5 分	4.7 分
立っている	30.8 分	4.2 分
歩いている	30.8 分	29.2 分
合計	3.5 時間	1.8 時間

無用のセグメンテーションが生じたとしても、若干のデータ量減少の可能性はあるものの、大きな問題とはならないと考えられる。

次に、図 3 に自動セグメンテーション手法により分割した行動のセグメントと、初期モデルによって推定された行動ラベルを示す。尚、スペクトル遷移度のピークを検出するにあたり、前処理として移動平均フィルタを用いてピークの検出を容易にしている。図 3 から、各セグメント内には、同種の推定ラベルが集中・連続していることが分かる。

図 3 の結果から、以降の実験では、推定されたラベルが 9 割以上同一のものであったセグメントを教師データとして採用することとした。この場合、合計約 3.5 時間相当のラベル無しデータの中から、合計約 1.8 時間相当のデータを新規の学習データとして採用することができた。行動種類ごとのラベル無しデータ量と提案手法による新規教師データ量をまとめたものを、表 1 に示す。

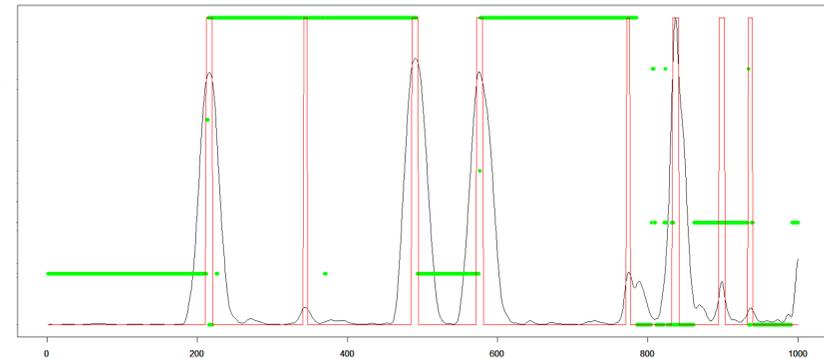


図 3 セグメントと推定ラベルの対応  
Fig. 3 Segmentation Results and Estimated Labels

#### 5.4 実験 2:提案手法による精度改善の評価

提案手法による精度改善効率を評価するに当たり行動種類ごとのデータ獲得機会の格差を無くす為、追加の学習データとして使用するデータは前述の方法で一度すべてにラベルづけをおこない、その中から各行動種類について数分ずつ均等に抽出して使用した。具体的な手順は以下の通りである。

- (1) 約 1.5 分相当のラベル付きデータを教師データとして利用し、教師付き学習を行い、これを初期モデルとする
- (2) 以下の再学習プロセスを繰り返す
  - (a) 既得モデルに対し約 3.5 時間相当のラベル無しデータを入力し、推定ラベルを出力する
  - (b) ラベル無しデータに対して自動セグメンテーションをかけ、同種の推定行動ラベルからなるセグメントを獲得する。そして、
  - (c) 各種行動ごとにセグメント群から同量ずつデータを採用し、合計約 15 分相当の推定ラベル付き新規データを教師データに追加する
  - (d) 既得モデルの再学習を行う

また、比較のために従来手法として、上記手順 (2)-(b) および (c) について「各種行動ごとに確信度の高いラベル推定をなされたデータから同量ずつ採用し、合計約 15 分相当の推定

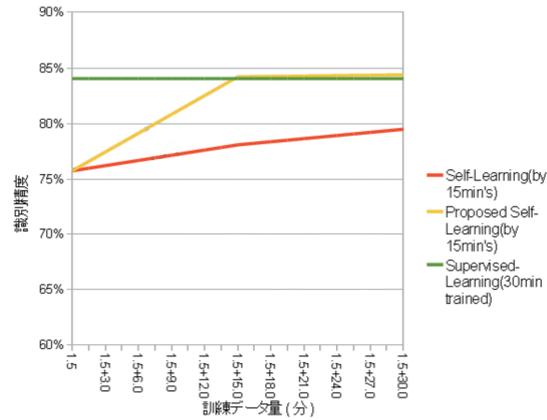


図 4 提案手法による精度推移  
Fig. 4 Proposed

ラベル付き新規データを教師データに追加する」と変更した場合（従来手法）についてデータを識別精度を測定した．それぞれの結果を図 4 に示す．図 4 には、同量のデータ学習データとして用いた場合の、教師付き学習における識別精度についても、同様に示してある．

図 4 より、従来手法では、30 分程度の再学習の後も教師付き学習と同程度の識別精度には到達しないのに対し、提案手法では、15 分程度の再学習により教師付き学習の場合と同等の識別率 (84.26%) を達成することができていることが分かる．提案手法を用いることで、同じ初期モデルを出発点として再学習プロセスを繰り返す際に、より有益な情報をモデルに反映させやすい結果であると考えられる．

## 6. おわりに

ラベル付き学習データ取得の労力低減の点から注目されている半教師付き学習では、一般に確信度や複数識別器の合意によって再学習の対象となるデータの採否が決定されることから、識別精度向上に大きく寄与するデータが排除されてしまう場合が多い．本稿では、この問題に対処するため、波形の自動セグメンテーション結果を基本として、再学習データとしての採否を決定する手法を提案した．提案手法では、加速度データをもとに自動セグメンテーションされた区間を単位として、区間全体について識別器が一定以上の割合で同一とみなされた場合にその区間全体を再学習用のデータとして採用する．このようにすることで、

区間内の「不明瞭なデータ」を採用する機会を増加させることができ、学習効率を高めることが期待できる．

7 種類の日常行動を対象として 6 個の加速度センサを用いてデータ収集実験を行い提案手法の評価を行った．そして、まず本研究で用いた自動セグメンテーション手法が加速度センサデータから行動の移り変わりを検出できることを確認した．次に、識別精度の改善について提案手法と従来手法の比較を行い、従来手法では 30 分程度の再学習の後も識別精度は伸び悩むのに対し、提案手法では 15 分程度の再学習でも教師付き学習の場合と同等の識別率を達成することができることを確認した．これらの結果から、提案手法では従来手法では排除されてしまったような学習に有益なデータを適切に用いることができ、学習効率の低下や最終的な識別精度の上昇を期待することができることが示された．

本研究では、7 種類の日常行動について、提案手法の有効性の確認を行ったが、実アプリケーションでは、より多くの行動種類について識別を行う必要がある場合がある．本手法は行動区間を自動セグメンテーション手法によって検出し、この区間全てについて再学習データへの採用を決定するため、自動セグメンテーションの性能が全体の学習性能に大きく影響する．今後、より多クラスの問題において自動セグメンテーション手法が適切に機能するかどうか、検証を行っていく予定である．

## 参 考 文 献

- 1) ATRPromotions, I.: Small Wireless Accelerometer Sensor WAA-001. <http://www.atrp.com/sensor01.html>.
- 2) Bao, L. and Intille, S.S.: Activity Recognition from User-Annotated Acceleration Data, *Pervasive 2004*, pp.1-17 (2004).
- 3) Dusan, S. and Rabiner, L.: On the Relation between Maximum Spectral Transition Positions and Phone Boundaries, *Proc. of the Interspeech 2006 — ICSLP*, pp. 645-648 (2006).
- 4) Guan, D., Yuan, W., Lee, Y.-K., Gavrilov, A. and Lee, S.: Activity Recognition Based on Semi-supervised Learning, *Proc. of the 13th IEEE International Conference on Embedded and Real-Time Computing Systems and Applications (RTCSA2007)*, pp.469-475 (2007).
- 5) Kern, N., Schiele, B. and Schmidt, A.: Multi-Sensor Activity Context Detection for Wearable Computing, *In Proc. EUSAI, LNCS*, pp.220-232 (2003).
- 6) Mallapragada, P.K., Jin, R., Jain, A.K. and Liu, Y.: SemiBoost: Boosting for Semi-supervised Learning, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.31, No.11, pp.2000-2014 (2009).

- 7) Ravi, N., D, N., Mysore, P. and Littman, M.L.: Activity recognition from accelerometer data, *In Proceedings of the Seventeenth Conference on Innovative Applications of Artificial Intelligence (IAAI, AAAI Press, pp.1541–1546 (2005).*
- 8) Stikic, M., Laerhoven, K.V. and Schiele, B.: Exploring Semi-Supervised and Active Learning for Activity Recognition, *Proc. of the 12th International Symposium on Wearable Computers (ISWC2008)*, pp.81–88 (2008).
- 9) Torralba, A., Murphy, K.P. and Freeman, W.T.: Sharing Visual Features for Multiclass and Multiview Object Detection, *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol.29, No.5, pp.854–869 (2007).
- 10) 伊藤 仁, 矢野雅文: 同時音声の知覚におけるスペクトル遷移の役割 (立体音響・音場制御/聴覚/一般), *信学技報*, Vol.105, No.230, pp.13–18 (2005-08-11).